



**Juho Kuiri**

**EDISTYNEIDEN DATA-ANALYYSIMENETELMIEN HYÖDYT LUOTTO- JA  
MAKSUHÄIRIÖRISKIEN HALLINNASSA**

Kandidaatintutkielma

Kauppätieteet

Toukokuu 2021

## SISÄLLYS

<b>1</b>	<b>JOHDANTO.....</b>	<b>4</b>
1.1	Tutkielman aihe.....	4
1.2	Tutkielman tavoite .....	5
1.3	Tutkimusmenetelmä ja rakenne .....	6
1.4	Tutkielman keskeiset tulokset.....	6
<b>2</b>	<b>LUOTTORISKIN ARVIOINTI JA HALLINTA .....</b>	<b>8</b>
2.1	Luottoriski .....	8
2.1.1	Maksuhäiriöriski ja luottotappioriski.....	8
2.1.2	Altistumisriski .....	9
2.1.3	Vaihtoehtoinen luottoriskien jako .....	10
2.2	Arviointi ja hallinta.....	10
<b>3</b>	<b>LUOTTORISKIN ARVIOINTI- JA ANALYYSITEKNIIKAT .....</b>	<b>15</b>
3.1	Perinteiset menetelmät.....	16
3.1.1	Subjektiivinen arviointi ja viitekehykset .....	16
3.1.2	Luottopisteytysmenetelmät .....	17
3.1.3	Perinteiset laskentamallit .....	19
3.2	Modernit menetelmät.....	21
3.2.1	Yleistä.....	21
3.2.2	Ohjatut koneoppimisalgoritmit .....	22
3.2.3	Ohjaamattomat koneoppimisalgoritmit .....	24
<b>4</b>	<b>PERINTEISTEN JA MODERNIEN MENETELMIEN VERTAILU.....</b>	<b>26</b>
4.1	Tarkkuus.....	26
4.1.1	Mittaussuureet.....	26
4.1.2	Vertailu .....	28
4.2	Liiketoiminnalliset vaikutukset.....	32

<b>5 YHTEENVETO .....</b>	<b>34</b>
<b>LÄHTEET .....</b>	<b>36</b>

## KUVIOT

<b>Kuvio 1. Luottoriskin arviointiprosessi (mukaillen Fight, 2004, s. 3).....</b>	<b>11</b>
<b>Kuvio 2. Jatkuva riskienhallintaprosessi (mukaillen Van Gestel &amp; Baesens, 2009, s. 41)....</b>	<b>13</b>
<b>Kuvio 3. Luottopäätösprosessi perustuen hakemuksen pisteytykseen (mukaillen Van Gestel &amp; Baesens, 2009, s. 98).....</b>	<b>18</b>
<b>Kuvio 4. Yksinkertainen päätöspuu (mukaillen Yiu, 2019).....</b>	<b>24</b>
<b>Kuvio 5. Mallien vertailu MCC:n avulla (mukaillen Bao, Lianju, Kong, 2019).....</b>	<b>30</b>

## TAULUKOT

<b>Taulukko 1. Luokittelumallien konfuusiomatriisi maksuhäiriöriskin ennustamisessa. ....</b>	<b>27</b>
<b>Taulukko 2. Random Forest -mallin, kNN-mallin, bNN- mallin ja logistisen regressiomallin vertailu (mukaillen Kruppa, Schwarz, Armingier &amp; Ziegler, 2013).....</b>	<b>29</b>

# 1 JOHDANTO

## 1.1 Tutkielman aihe

Rahoitusmarkkinoiden kilpailu on kiristynyt viime vuosina matalien korkojen sekä kasvaneen kysynnän vuoksi. Yksityishenkilöiden, kotitalouksien ja yritysten rahoitustarpeet ovat kasvaneet, minkä seurauksena rahoituslaitosten luottopäätösprosesseihin ja niiden kehittämiseen on ryhdytty panostamaan entistä enemmän. Luottoriskien hallinta, joka tähtää luottotappioiden minimointiin ja vastuullisuuteen, on noussut näistä syistä entistä tärkeämmäksi rahoitusprosessien osaksi. Luottoriskien hallinnan merkitys on lisäksi korostunut erilaisten finanssikriisien seurauksena. Erityisenä luottoriskien vastuullista hallintaa korostavana hetkenä voidaan mainita vuoden 2008 finanssikriisi, jonka seurauksena rahoituslaitosten toimintaa finanssimarkkinoilla on säännelty runsaasti esimerkiksi nostamalla pääomavaatimuksia. Tästä syystä rahoituslaitosten vakavaraisuus on parantunut huomattavasti verrattuna finanssikriisiä edeltävään aikaan. Finanssikriisi korosti luottoriskien hallinnan roolia ja tärkeyttä kriisin synnyttyä heikoin perustein myönnettyistä asuntolainoista Yhdysvalloissa. Luottoriskien hallinnan ja erityisesti hallintamenetelmien kehittäminen on oleellinen osa kriisien ehkäisyä tulevaisuudessa. Kansainvälisten sopimusten ja sääntelyn, kuten Basel III -sopimuksen lisäksi rahoituslaitosten tulee jatkuvasti kehittää sisäisiä prosessejaan hallitakseen luottoriskejä optimaalisesti.

Basel II -sopimuksen jälkeen rahoitusalan instituutioille ja yrityksille keskeistä riskinhallintaa on lähestytty käyttämällä pienimuotoisia regressioanalyysitekniikoita, jotka pyrkivät ennustamaan lainaajan maksukykyä muodostamalla arvion erilaisten muuttujien, kuten taloudellisten fundamenttien perusteella (Resti & Sironi, 2014 via Moscatelli, Parlapiano, Narizzano & Viggiano, 2020). Perinteiset tilastotieteelliset mallit eivät kuitenkaan välttämättä kykene ennustamaan luottoriskiä ja velallisen maksukykyä riittävän hyvin monimutkaisissa markkinaympäristöissä ja niiden muutoksissa. Vuoden 2008 finanssikriisin myötä esiin nousivat esimerkiksi seuraavat heikkoudet perinteisissä luottoriskin mallinnusmenetelmissä: perinteisten mallien hitaus sopeutua taloudellisten tilanteiden muutoksiin, ja niiden rajoittunut kyky

mallintaa monimutkaisia suhteita talouteen ja luotonantoon liittyvien muuttujien välillä (Moscatelli, Parlapiano, Narizzano, & Viggiano, 2020). Suurten datamäärien hyödyntäminen on yleistynyt lähes kaikilla liiketoiminta-aloilla. Tarvittavien datatyökalujen käytön helpottumisen vuoksi rahoituslaitoksilla ja muilla aktiivisesti luottoriskiä kokevilla instituutioilla ei ole syytä olla tutkimatta modernimpia vaihtoehtoja, joiden avulla erilaisten, ei-perinteisten tekijöiden vaikutusta velallisen maksukykyyn ja luotettavuuteen voidaan arvioida. Tämä tutkielma käsittelee edistyneiden data-analyysitekniikoiden, kuten erilaisten koneoppimismallien hyötyjä osana luottoriskien hallintaa.

## 1.2 Tutkielman tavoite

Olemassa olevat tutkimukset erilaisten data-analyysimenetelmien ja koneoppimismallien hyödyistä keskittyvät usein menetelmien matemaattiseen kuvaamiseen ja niiden ominaisuuksien syvälliseen tarkasteluun. Tämä tutkielma käsittelee menetelmien ominaisuuksia ja hyötyjä yleisemmällä tasolla sekä pyrkii vastaamaan alla esiteltävään tutkimuskysymykseen. Varsinaisen päättämiskysymyksen tueksi on laadittu seuraavat kysymykset, joiden avulla tutkimuskysymykseen voidaan vastata mahdollisimman hyvin ja selkeästi.

*Mitä keskeisiä hyötyjä edistyneillä data-analyysimenetelmillä saavutetaan luottoriskien hallinnassa verrattuna perinteisiin metodeihin?*

1. Mitä luottoriski tarkoittaa käsitteenä, ja mistä se koostuu?
2. Miten luottoriskiä arvioidaan ja hallitaan?
3. Mitä erilaisia menetelmiä luotto- ja erityisesti maksuhäiriöriskin määrittämiseen voidaan soveltaa?
4. Miten modernit menetelmät eroavat perinteisistä menetelmistä?

Tutkimuskysymykseen pyritään vastaamaan liiketoiminnallisten hyötyjen kautta syventymättä liikaa erilaisten data-analyysi- ja koneoppimismallien matemaattisiin ominaisuuksiin. On kuitenkin mainittava, että menetelmien hyötyjen ja erojen kuvaaminen on selkeintä niiden tuottamien lukujen kautta. Data-analyysin ja

koneoppimisen potentiaalin ja hyödyllisyyden tutkiminen osana luottoriskien hallintaa on tärkeää, koska tekoälyn käyttö tulee yleistymään huomattavasti rahoitusallalla. Analyysimenetelmät ja erityisesti koneoppimismallit kehittyvät jatkuvasti, ja uusien menetelmien käyttöön liittyvät investoinnit kasvavat trendinomaisesti. On tärkeää ymmärtää, mitä hyötyjä uudet menetelmät tarjoavat perinteisiin luottoriskinhallintamenetelmiin verrattuna.

### **1.3 Tutkimusmenetelmä ja rakenne**

Tutkielma toteutetaan kirjallisuuskatsauksena, ja tavoitteena on muodostaa johtopäätöksiä edistyneiden data-analyysimenetelmien ja erityisesti koneoppimisen hyödyistä osana luottoriskien hallintaa. Johtopäätösten muodostamiseksi tutkielmassa tarkastellaan olemassa olevaa tutkimuskirjallisuutta ja vertaisarvioituja artikkeleita ja vertaillaan tutkimustuloksia. Tutkielma etenee seuraavien päälukujen mukaisessa järjestyksessä: johdanto (1), luottoriskin arviointi ja hallinta (2), luottoriskin arviointi- ja analyysitekniikat (3), perinteisten ja modernien menetelmien vertailu (4) sekä yhteenveto (5). Aluksi keskitytään luottoriskin liiketoiminnalliseen määritelmään ja siihen liittyvään teoriaan, minkä jälkeen syvennytään luotto- ja erityisesti maksuhäiriöriskin arviointiprosessin sekä menetelmien tarkasteluun.

Tutkielman aiheeseen liittyvä tutkimuskirjallisuus koostuu suurimmaksi osaksi tieteellisistä artikkeleista, joissa käsitellään erilaisia malleja ja tapoja, joilla luottoriski voidaan määrittää. Tutkimuskirjallisuus erittelee malleja niiden tarkkuuden ja ominaisuuksien pohjalta keskittyen erityisesti kuvaamaan, miten mallit toimivat. Luottoriskin määritystä ja maksukyvyn ennustamista kuvataan kirjallisuudessa sekä kuluttajien että yritysten luottojen näkökulmasta.

### **1.4 Tutkielman keskeiset tulokset**

Tutkielman keskeiset tulokset tukevat luotto- ja maksuhäiriöriskejä koskevaa olemassa olevaa tutkimuskirjallisuutta ja tutkimustuloksia. Tutkielmassa muodostetaan kattava ja monipuolinen vastaus määritettyyn tutkimuskysymykseen. Keskeiset päätelmät edistyneiden data-analyysimenetelmien hyödyistä luotto- ja

maksuhäiriöriskien hallinnassa antavat tukea näiden menetelmien hyödyntämiselle riskienhallintaprosesseissa.

Modernit menetelmät, kuten erilaiset koneoppimismallit, kykenevät tutkimuskirjallisuuden mukaan arvioimaan maksuhäiriöriskiä keskimäärin tarkemmin kuin perinteiset menetelmät. Useita toisiaan tukevia menetelmiä hyödynnettäessä erilaisten mallikokonaisuuksien muodossa saavutetaan parempi arvioinnin tarkkuus lähes poikkeuksetta. Liiketoiminnallisiin vaikutuksiin liittyvät tulokset jakautuvat aikavälin perusteella. Lyhyellä aikavälillä liiketoiminnassa tulisi ottaa huomioon moderneiden menetelmien käytöstä aiheutuvat tuotot ja verrata niitä menetelmien implementoinnista aiheutuviin kustannuksiin. Tietyissä yksinkertaisissa analyysitarkoituksissa moderneilla menetelmillä ei myöskään saavuteta merkittäviä hyötyjä, jolloin niiden hyödyntäminen ei ole perusteltua. Pitkällä aikavälillä näiden menetelmien hyödyntäminen on sen sijaan kannattavaa sekä liiketoiminnallisesti että yhteiskunnallisesti.

## 2 LUOTTORISKIN ARVIOINTI JA HALLINTA

Luottoriskien arvioinnilla ja hallinnalla tarkoitetaan rahoituslaitosten riskienhallinnan prosessia, jonka tavoitteena on minimoida liiketoimintaa kohtaavat myönnytyistä luotoista aiheutuvat riskit. Luottoriski on suurin yksittäinen rahoituslaitosten liiketoimintaa koskeva riskityyppi, minkä vuoksi sen tarkoituksen mukainen hallinta on erittäin tärkeää. Kuten aiemmassa pääluvussa mainittiin, rahoituslaitosten toiminnalta edellytetään lisäksi vastuullisuutta erilaisten kansainvälisten säädöksien avulla. Tämä pääluku käsittelee luottoriskiä käsitteenä, sekä sen arviointia ja hallintaa. Erityistä huomiota kiinnitetään arviointi- ja hallintaprosessien kuvaamiseen.

### 2.1 Luottoriski

Luottoriski tarkoittaa lainanantajan kokemaa riskiä tilanteesta, jossa velallinen organisaatio tai oikeushenkilö ei maksa lainaamansa summaa takaisin rahoittajalle lainan ehtojen mukaisesti. Yleisesti ottaen voidaan todeta luottoriskin olevan suurin yksittäinen rahoituslaitosten ja lainanantajien toimintaan liittyvä riski, sillä liikevaihto muodostuu rahoitustoiminnan tuotoista. Luottoriski voidaan jakaa erilaisiin tekijöihin lainan elinkaaren ja potentiaalisten tappioiden realisoitumistavan mukaan. (Van Gestel & Baensens, 2009, s. 25.) Näitä tekijöitä käsitellään seuraavissa alaluvuissa.

#### 2.1.1 Maksuhäiriöriski ja luottotappioriski

Maksuhäiriöriski (default risk, probability of default) tarkoittaa lainanantajaa kohtaavan velallisen maksukyvyttömyyden tai -häiriön todennäköisyyttä. Tämä todennäköisyys ilmaistaan tyypillisesti lukuna nollan ja yhden välillä. Lainan myöntävä rahoituslaitos arvioi maksuhäiriöriskin tavallisesti asiakaskohtaisesti. (Van Gestel & Baensens, 2009, s. 25.) Suomen kielessä tätä riskiä käsitellään usein pelkkänä luottoriskinä, vaikka kyseessä on todellisuudessa luottoriskin yksi tekijä. Maksuhäiriöriski liittyy erityisesti lainaajaan ja oletamaan siitä, että mikäli velallinen ei kykene hoitamaan yhtä maksuvelvoitetta, epäonnistuu velallinen myös muissa maksuvelvoitteissa ja on tämän vuoksi maksukyvytön (Treacy & Carey, 2000). Maksuhäiriöriskin mallinnus ja hallinta on yleisesti ottaen kehittyneempää verrattuna



muiden luottoriskin osatekijöiden hallintaan (Van Gestel & Baesens, 2009, s. 29). Tämä tutkielma keskittyy erityisesti tutkimaan modernien analyysitekniikoiden hyödyntämisen avulla saavutettavia hyötyjä maksuhäiriöriskin arvioinnin sekä hallinnan näkökulmasta. Seuraavissa alaluvuissa käsiteltävät muut luottoriskin tekijät on kuitenkin tärkeä ymmärtää luottoriskikäsitteen laajuuden vuoksi.

Luottotappioriski (loss risk, loss given default), joka liittyy maksuhäiriöriskin realisoitumiseen, määrittää tappion osuuden riskialtistuksesta. Luottotappioriski ilmaistaan prosenttiyksikköinä nollan (0) ja sadan (100) välillä siten, että mikäli rahoituslaitoksen luottotappio käsittää koko lainatun summan, on luottotappio 100 %. Luottotappioprosentti voi joissain tilanteissa ylittää 100 prosenttiyksikköä; esimerkiksi tilanteessa, jossa luottotappiosta koituu muitakin kuluja (oikeusmenettelyt, takaisinperintä). Luottotappioprosentin vastakohta on takaisinmaksuprosentti, joka puolestaan tarkoittaa prosentuaalista osuutta luoton määrästä, jonka rahoituslaitos saa takaisin. (Van Gestel & Baesens, 2009, s. 26.)

### 2.1.2 Altistumisriski

Altistumisriski (exposure risk) tarkoittaa luotonantajan epävarmuutta vastapuolen käyttämästä todellisen luoton määrästä. Kiinteäsummaisten lainojen ja velkakirjojen sijaan tämän epävarmuuden lähteitä ovat esimerkiksi luottolimiitit ja -kortit sekä luottosopimukset, joissa velalliselle myönnettävä luoton määrä on joko rajoittamaton tai rajoitettu tiettyyn pisteeseen. Tämän kaltaisissa luottosopimuksissa käytössä olevan luoton määrä perustuu asiakkaan tarvitseman likviditeetin määrään ja on helposti korotettavissa asiakkaan aloitteesta. Altistumisriski voi siis kasvaa, mikäli luottosopimuksen vastapuoli haluaa korottaa luottolimiittiä. Rahoituslaitokset pyrkivät suojautumaan riskiltä esimerkiksi erilaisten kovenanttien eli luottosopimusten erityisehtojen avulla, joita hyödyntämällä rahoituslaitos voi muuttaa ja erityisesti rajoittaa luoton limiittiä olosuhdemuutosten vuoksi. (Van Gestel & Baesens, 2009, s. 28.)

### 2.1.3 Vaihtoehtoinen luottoriskien jako

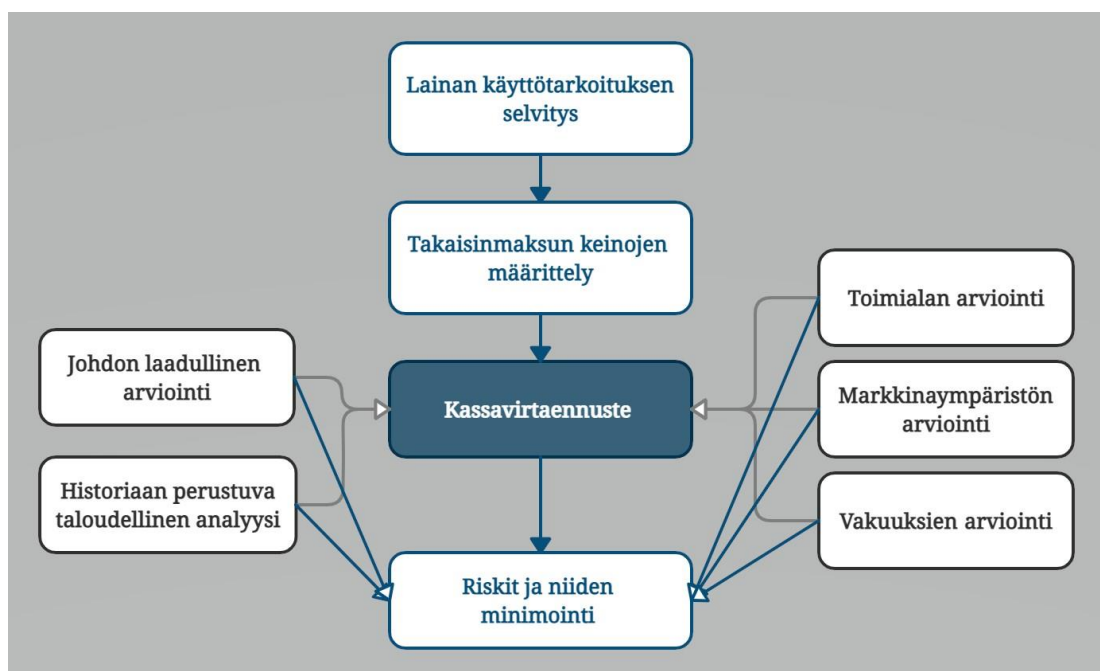
Luottoriski voidaan jakaa edellisten osakomponenttien lisäksi myös ajallisesti kahteen eri kategoriaan: maksusuoritusta edeltävään sekä maksusuorituksen aikaiseen riskiin. Suoritusta edeltävällä riskillä tarkoitetaan lainanantajan kokemaa riskiä lainan maturiteetin aikana ennen takaisinmaksua eli suoritusta. Suoritusta edeltävä riski voi realisoitua esimerkiksi velallisen mennessä konkurssiin kesken lainan maturiteetin. On myös huomioitava, että tämä riski voi realisoitua, kun velallisen riskiluokituksen heikentyminen vaikuttaa lainan hintaan. Kyseisessä tilanteessa lainan markkinoilta ostaneelle toimijalle aiheutuu tappioita, mikäli laina likvidoidaan eli myydään eteenpäin. Tappiot muodostuvat ostohinnan ja lainan alentuneen myyntihinnan erotuksesta. Erityistä tälle riskille on sen pitkä kesto: laina-ajat ovat tyypillisesti useita vuosia.

Takaisinmaksun suorittamiseen liittyvä riski puolestaan käsittää mahdolliset tappiot, jotka voivat realisoitua lainanantajalle tai velkojalle takaisinmaksun yhteydessä. Tämä riski voi realisoitua esimerkiksi tilanteessa, jossa laina maksetaan takaisin välittäjän/välittäjien kuten kansainvälisten pankkien kautta. Mikäli maksun välittävä pankki tekee konkurssin tai muuttuu maksukyvyttömäksi liikkeellä olevan lainan takaisinmaksun aikana, lainanantajalle voi syntyä tappioita (Van Gestel & Baensens, 2009, s. 24.)

## 2.2 Arviointi ja hallinta

Rahoitusalan toimijoiden on tärkeää onnistua arvioimaan ja hallitsemaan luottoriskejä mahdollisimman hyvin. Luottoriskin arvioinnin laajuus selvitetään luottotarpeen ja sen piirteiden perusteella. Arviointiin vaikuttavat muun muassa lainatarpeen koko ja luonne, tulevaisuuden potentiaali asiakassuhteen muodossa vastapuolen kanssa, vakuuksien saatavuus tarpeen vaatiessa ja mahdollisesti olemassa oleva asiakassuhde vastapuolen kanssa. Lisäksi rahoituslaitos voi hankkia mahdollisuuksien mukaan tietoa lainaa hakevan osapuolen aikaisemmasta maksuhistoriasta, esimerkiksi luottotietojen muodossa. Vaikeissa tilanteissa rahoituslaitos voi joutua myös hyödyntämään lakiasiantuntemusta, mikäli luottoriski realisoituu. (Fight, 2004, s. 2.)

Yleisen käytännön mukaan luottoriski arvioidaan luotonantajan toimesta jokaisen lainaa hakevan osapuolen kohdalla erikseen, ottaen huomioon erilaiset maksukykyyn liittyvät tekijät kuten vakavaraisuus, luottotiedot, vakuudet ja käytettävät varat. Yritysten suhteen kriittistä on myös arvioida yrityksen potentiaali, liiketoiminnan tehokkuus sekä tunnusluvut, jotta lainaa hakevan osapuolen maksukyky ja mahdollinen tarve vakuuksille saadaan selville. Luottoriskin tehokas ja onnistunut arviointi vaatii myös muiden tekijöiden, kuten luottoa hakevan osapuolen toimintaympäristön sekä toimialan arviointia. Luottoriskin arviointia erityisesti yritysten näkökulmasta havainnollistetaan kuviossa 1.



**Kuvio 1. Luottoriskin arviointiprosessi (mukailen Fight, 2004, s. 3).**

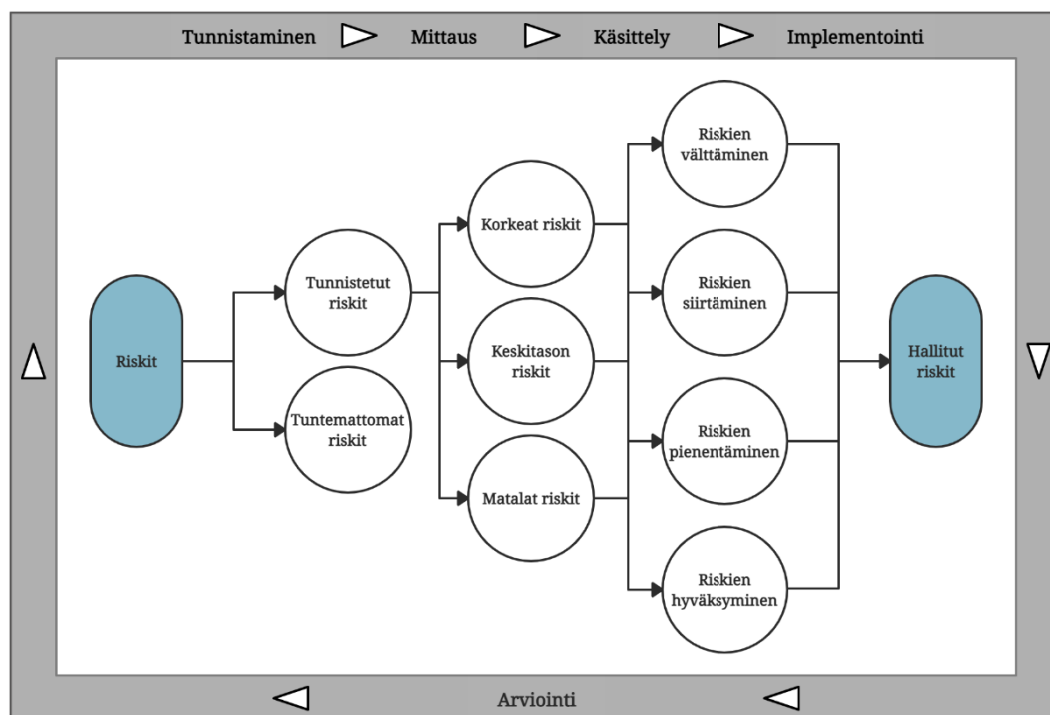
Luottoriskin arviointi tilanteessa, jossa luottoa hakeva osapuoli on yritys, koostuu Fightin (2004) mukaan neljästä vaiheesta. Luoton tarpeen ja käyttötarkoituksen selvittäminen on ensiarvoisen tärkeää rahoituslaitoksen näkökulmasta, koska erilaisia luottotuotteita koskevat erilaiset ehdot ja säännökset. Lisäksi käyttötarkoitus antaa rahoituslaitokselle tietoa siitä, tullaanko luottoa käyttämään tuottavaan, sijoitus- tai investointiluontoiseen toimintaan, vai kenties perustason toiminnan rahoittamiseen esimerkiksi taloudellisten haasteiden ilmetessä. Tämän askeleen jälkeen määritellään takaisinmaksukeinot. Ensimmäinen keino tarkoittaa tyypillisesti lainan lyhentämistä

erissä tai kerrallaan käteismaksuina, maksusuunnitelman mukaisesti. Toinen keino puolestaan toimii varasuunnitelmana rahoittavalle osapuolelle tilanteessa, jossa velallisen maksukyky heikkenee, eikä luotolle voida tehdä suorituksia ensimmäisen maksukeinon määrittelemistä lähteistä. Tämä toinen, takaisinmaksun varmistava maksukeino on tyypillisesti luotolle asetettu vakuus. Tilanteessa, jossa toiseen keinoon joudutaan tukeutumaan, vakuudeksi asetettu varallisuuserä, kuten kiinteistö tai sijoitus pääomamarkkinoille likvidoidaan tarpeen vaatiessa, ja varallisuuserän myynnistä saamat varat käytetään luoton takaisinmaksuun.

Kun lainan takaisinmaksukyky on arvioitu maksukeinojen osalta, rahoituslaitos pyrkii arvioimaan velallisen käytössä olevat kassavirrat, joiden avulla luoton takaisinmaksu tapahtuu. Tässä vaiheessa luottoriskien arviointia luotonantajan tulee ottaa huomioon ulkoiset, luottoa hakevan yrityksen, organisaation tai henkilön kassavirtoihin vaikuttavat asiat, kuten esimerkiksi toimialan muutokset sekä globaalit talousennusteet. Arvioimalla ja ottamalla huomioon erilaiset asiakkaan maksukykyä heikentävät skenaariot, rahoituslaitos kykenee varautumaan riskeihin paremmin. Kun oleelliset tekijät on otettu huomioon ja suurimmat asiakaskohtaiset riskit on määritelty, riskien aktiivinen hallinta alkaa. Tässä vaiheessa asiakkaan maksukykyä ja luottoriskejä arvioidaan jatkuvasti luoton maturiteetin aikana, jonka avulla rahoituslaitos kykenee minimoimaan riskit parhaan kykynsä mukaisesti. On kuitenkin huomautettava, että luottoriskien arviointi ja kartoitus ei tapahdu samassa mittakaavassa esimerkiksi henkilöasiakkaiden pienempien luottojen myöntämisen yhteydessä. Perusidea on kuitenkin sama; uuden luottoa hakevan asiakkaan luottotarve ja maksukyky kartoitetaan, jonka jälkeen analysoidaan maksukykyyn riittävyys suhteutettuna haettavan luoton määrään. Jos asiakkaan maksukyky riittää ja asiakas kykenee toimittamaan siitä rahoituslaitokselle todisteita, luotto myönnetään ja asiakassuhdetta ryhdytään hoitamaan aktiivisesti, laajuuden riippuessa asiakastyypistä. Jos maksukyky on puolestaan puutteellinen, asiakkaan luottohakemus hylätään.

Ylempänä käsitellyn luottoriskien arviointiprosessin voi ajatella tähtäävän kaikkien luotonantajan ja luottoa hakevan osapuolen välisen liiketoiminnan aiheuttamien riskien määrittämiseen. Riskien pelkkä määrittäminen ei kuitenkaan riitä. Riskien

asianmukainen jatkokäsittely ja hallinta on erittäin tärkeää, jotta mahdollisiin muutoksiin asiakkaan ja liiketoiminnan riskiprofilissa kyetään reagoimaan. Tätä koko asiakassuhteen kattavaa riskienhallinnan prosessia voidaan havainnollistaa kuvion 2 avulla.



**Kuvio 2. Jatkuva riskienhallintaprosessi (mukaillen Van Gestel & Baesens, 2009, s. 41).**

Rahoituslaitoksen riskit pyritään tunnistamaan mahdollisimman hyvin, jonka jälkeen ne luokitellaan korkeisiin, keskitasoihin ja mataliin riskeihin. Tämän jälkeen päätetään, miten riskejä käsitellään osana riskienhallinnan strategiaa. Riskejä voidaan käsitellä neljällä eri tavalla, käsittelyn valikoituessa tyypillisesti riskin vakavuuden perusteella. Tunnistettu riski voidaan joko välttää, sitä voidaan pienentää, se voidaan hyväksyä tai se voidaan siirtää. Luottoriskejä koskien rahoituslaitos voi välttää riskin olemalla sijoittamatta lainoihin tai muihin tuotteisiin. Riskien pienentäminen puolestaan tapahtuu rahoituslalla tyypillisesti erilaisten vakuuksien, kuten aiemmin

käsiteltyjen omaisuuserien tai kovenanttien sekä takauksien määrittämisellä. Riskien hyväksyminen tarkoittaa kirjaimellisesti sitä, että luoton antava osapuoli hyväksyy luoton myöntämiseen liittyvät riskit. Luotonantajat hyväksyvät riskin pääsääntöisesti herkemmin, jos riskiin liittyvä sijoitus on hajautettu, jolloin riski on kokonaisuudessaan pienempi. Viimeisenä vaihtoehtona luotonantajalle on riskin siirtäminen. Luoton antaja voi toimia näin esimerkiksi hankkimalla vakuutuksen. (Van Gestel & Baesens, 2009, s. 42.)

Riskienhallintaprosessi ei kuitenkaan pääty implementointivaiheeseen, vaan riskien hallinta jatkuu arviointivaiheen muodossa koko asiakkuuden ajan (Van Gestel & Baesens, 2009, s. 41–42). Vaikka tämä tutkielma käsittelee riskienhallintaa luottoriskien näkökulmasta, voidaan kyseisen prosessin ajatella pätevän myös muiden riskityyppien hallinnassa. Riskienhallinnan tarkoittaessa yksinkertaistetusti liiketoimintaa kohtaavien uhkien tunnistamista ja minimointia, nykyaikaisessa jatkuvasti muuttuvassa liiketoimintaympäristössä menestyminen vaatii jatkuvaa uhkien tarkastelua.

### 3 LUOTTORISKIN ARVIOINTI- JA ANALYYSITEKNIIKAT

Luottoriskien arviointi- ja analyysitekniikat pyrkivät ensisijaisesti ennustamaan luottoa hakevan osapuolen riskisyyden rahoituslaitokselle sijoituksen näkökulmasta. Luottoa hakevan osapuolen riskitaso ilmaistaan arvioinnissa tyypillisesti maksuhäiriöriskinä. Luottoriskien arviointi ja lopulta määräytyminen pyrkivät siis pelkistetyksi vastaamaan kysymykseen *kykeneekö asiakas selviämään maksuvelvoitteistaan?* Kuten aiemmassa maksuhäiriöriskiä käsitelleessä alaluvussa mainittiin, asiakkaan maksukyky ja sen myötä maksuhäiriötapahtumaa koskeva riski ilmaistaan tyypillisesti todennäköisyytenä tai numeraalisena arvona, joka muodostuu tiettyjen luottoa hakevan osapuolen ominaisuuksien perusteella. Tämä erilaisten analyysitekniikoiden avulla saatu arvo tai todennäköisyys on tärkeässä roolissa rahoituslaitosten prosesseissa, joiden avulla luottopäätöksiä tehdään. Erilaisia asiakkaan maksukykyä sekä asiakkuuden tilaa kuvaavia pisteytyksiä käytetään rahoituslalla luottoriskien ilmaisemiseen ja arviointiin koko asiakassuhteen ajan. Pisteytysmenetelmien suosioon on johtanut erityisesti luottihakemusten pisteytyksen positiiviset vaikutukset asiakkaiden maksukyvyn ennustamiseen. (Van Gestel & Baensens, 2009, s. 93–95.) Pisteytykset ja luottovirastojen antamat maksukykyarviot eivät kuitenkaan ole ainoita tapoja arvioida asiakkuuden aiheuttamia luottoriskejä. Modernit teknologiat eivät pyri antamaan asiakkaan maksukyvyllle lukuarvoa tietyn tuloskortin tai viitekehysten mukaan, vaan luokittelemaan maksukyvyn binäärisesti. Vaikka erilaisia analyysimenetelmiä on lukuisia, niiden käyttöä yhdistää yleinen käyttötarkoitus ja sen tuomat hyödyt: kun asiakkaan maksukyky ja sen seurauksena maksuhäiriöriski voidaan arvioida tehokkaasti ennen lainan myöntämistä, rahoituslaitokset kykenevät välttämään luottotappiot paremmin.

Vaikka pisteytysjärjestelmiä sekä muita perinteisiä menetelmiä käytetään edelleen yleisesti luottoriskien arviointiin, modernit tekoälyyn perustuvat tekniikat ovat nostaneet päätään viime vuosien aikana, erityisesti Basel II sopimuksen, globaalin finanssikriisin sekä teknologisen kehityksen seurauksena. Menetelmien kehityksen vuoksi

perinteisten ja modernien analyysimenetelmien vertailu on erittäin tärkeää. Seuraavissa alaluvuissa käsitellään erilaisia arviointi- ja analyysitekniikoita saatavilla olevan tutkimuskirjallisuuden kautta, ja pyritään muodostamaan kuva erilaisten tekniikoiden vahvuuksista sekä heikkouksista erityisesti maksuhäiriöriskin määrittämisessä. Tutkimuskirjallisuus, jota tässä tarkoituksessa hyödynnetään, on pääosin vertaisarvioitua ja koostuu aikakauslehdissä julkaistuista artikkeleista. Teoreettisen viitekehyksen määrittelemiseen käytetyt lähteet koostuvat luottoriskien hallintaa ja arviointia käsittelevistä kirjoista.

### **3.1 Perinteiset menetelmät**

#### **3.1.1 Subjektiiivinen arviointi ja viitekehykset**

Asiakaskohtaista maksuhäiriöriskiä on perinteisesti arvioitu subjektiivisesti ennen kehittyneempien analyysitekniikoiden ja menetelmien syntyä, usein erilaisten viitekehysten perusteella. Tällaisia viitekehyksiä ovat esimerkiksi yleisesti edelleen käytössä oleva asiakkaan ominaisuuksia koskeva viiden C:n malli (Corporate Finance Institute, 2021; Van Gestel & Baensens, 2009, s. 94) sekä muut viitekehykset kuten LAPP-metodi<sup>1</sup> (Benz, 1979 via Abbadi & Abu Karsh, 2013), Viiden P:n malli<sup>2</sup>, CAMPARI-malli<sup>3</sup> sekä FAPE-metodit<sup>4</sup> (Abbadi & Abu Karsh, 2013). Nämä viitekehykset pyrkivät jakamaan luottoa hakevan osapuolen maksukykyyn liittyvät ominaisuudet sekä niiden tarkastelun eri osa-alueisiin. Mallien peruserä on sama, mutta lähestymistavat vaihtelevat mallien ja metodien välillä. Benzin (1979) kehittämä LAPP-metodi on suunniteltu yritysten luottohakemusten arviointia varten (Abbadi & Abu Karsh, 2013), kun taas viiden C:n malli käsittelee asiakkaan luottokelpoisuutta yleisten ominaisuuksien kautta. Ominaisuuksien jakotapa liittyy erityisesti erilaisten riskien arviointiin ja niihin varautumiseen. Viiden C:n mallissa jakotapa on seuraava: luottoa hakevaa osapuolta arvioidaan maksukapasiteetin,

---

<sup>1</sup> LAPP-metodissa mitataan asiakkaan likviditeettiä, aktiivisuutta, voitollisuutta ja potentiaalia.

<sup>2</sup> Viiden P:n malli käsittää asiakkaan luonteen, luoton tarkoituksen, maksutavan, vakuudet ja luoton valvonnan.

<sup>3</sup> CAMPARI-mallissa tarkastellaan asiakkaan luonnetta, maksukykyä, omarahoitusosuutta, luoton tarkoitusta, sen määrää, maksuehtoja ja vakuuksia.

<sup>4</sup> FAPE-metodeissa asiakkaan maksukykyä arvioidaan analysoimalla luotonhakijan taloudellista asemaa dokumenttien ja aiemman luottohistorian perusteella.



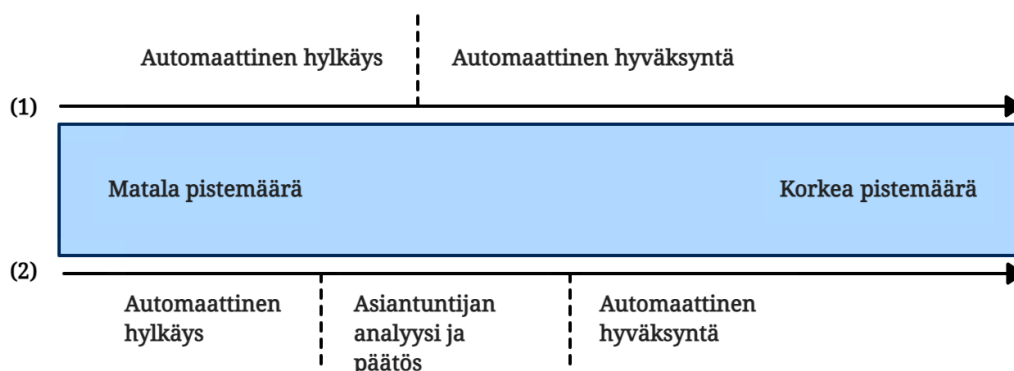
sijoitetun pääoman, vakuuksien, kotimaan taloudellisen sekä poliittisen tilanteen ja luonteen perusteella.

Viitekehykset ja pelkästään niiden perusteella tapahtuva maksuhäiriöriskien arviointi on vähentynyt huomattavasti rahoituslaitosten siirryttyä käyttämään erilaisia asiakkaiden pisteytysmenetelmiä sekä luottovirastojen antamia arvioita yksityishenkilöiden sekä yritysten luottohistoriasta. Koska viitekehykset nojaavat osin luottopäättösasiantuntijan subjektiiviseen käsitykseen luottoa hakevan osapuolen luonteesta ja näin ollen luotettavuudesta, luottopäätösten tekeminen objektiivisesti niiden avulla on vaikeaa. Vaikka arvioita asiakkaiden maksuhäiriöriskistä ei pääsääntöisesti enää tehdä pelkästään viitekehysten ja subjektiivisen arvioinnin perusteella, kyseisiä keinoja käytetään edelleen tilanteissa joissa luottoa hakevan osapuolen ominaisuuksista ja maksukyvyistä ei ole saatavilla riittävästi tietoa (Van Gestel & Baensens, 2009, s. 94). Subjektiivista näkemystä tarvitaan maksuhäiriöriskin suhteen myös tilanteissa, joissa automatisoidut järjestelmät ja niiden antama analyysitulokset ei anna riittävän varmaa arviota luottoa hakevan osapuolen maksukyvyistä. Näiden käyttötarkoitusten lisäksi viitekehykset toimivat yleisesti rahoituslaitosten ohjenuorana muiden luottoriskin tekijöiden, kuten luottotappioriskin ja altistumisriskin määrittämisessä. Maksuhäiriöriskin määrittämisessä viitekehysten käyttöön nojaaminen on nykyaikana kuitenkin harvinaista.

### 3.1.2 Luottopisteytysmenetelmät

Maksuhäiriöriskin mahdollisimman objektiivista ja tehokasta asiakaskohtaista arviointia varten on vuosien varrella kehitetty useita erilaisia menetelmiä. Yksi, hyvin monimuotoisesti käytetty menetelmä, on asiakaskohtainen luottopisteytys (credit scoring), joka on saanut alkunsa vähittäispankkitoiminnan luottihakemusten arvioinnista. Maksuhäiriöriskiä koskien tärkeä pisteytysmenetelmä liittyy erityisesti luottoa hakevan osapuolen hakemuksen pisteyttämiseen jonkin tietyn pisteytystaulukon mukaisesti. Tämä pisteytys tapahtuu ennen luoton myöntämistä ja antaa lopulta rahoituslaitokselle tietoa asiakkaan todennäköisyydestä ajautua maksuhäiriötilanteeseen. Luottihakemuksia pisteytettiin yksi asiakkaan ominaisuus kerrallaan ensin manuaalisesti pisteytystaulukoiden viitearvojen mukaisesti ja pisteet

laskettiin yhteen, jolloin asiakkaan maksukyvyille ja maksuhäiriöriskille saatiin numeraalinen arvo. Pisteytysjärjestelmien menestys manuaalisena maksuhäiriöriskin määrittämiskeinona luottopäätösprosessissa on johtanut erilaisten matemaattisten mallien ja automatisoitujen järjestelmien kehitykseen luottopäätösten nopeuttamiseksi. (Van Gestel & Baesens, 2009, s. 94–97.) Kyseinen kehitys on hyvin ymmärrettävää – rahoituslaitokset säästävät huomattavan määrän aikaa ja rahaa, kun luottopäätöksiä voidaan tehdä nopeasti prosesseja erityisen paljon kuormittaville asiakasryhmille, kuten henkilöasiakkaille. (Van Gestel & Baesens, 2009, s. 97.) Kuvio 3 havainnollistaa hakemusten pisteytysjärjestelmien peruseriaa sekä luottopäätöksen muodostamista kahden eri järjestelmätyypin avulla.



**Kuvio 3. Luottopäätösprosessi perustuen hakemuksen pisteytykseen (mukaillen Van Gestel & Baesens, 2009, s. 98).**

Esimerkkijärjestelmässä numero yksi (1) automatisoitu järjestelmä laskee luottoa hakevalle asiakkaalle maksukykyä kuvaavan pistemäärän luottopisteytysmallin tai -taulukon mukaisesti hyödyntäen laskutoimituksessa erilaisia myöhemmin tässä tutkielmassa käsiteltäviä matemaattisia malleja, joiden avulla järjestelmä antaa joko myönteisen päätöksen (määriteltä rajaa korkeampi pistemäärä) tai kielteisen päätöksen (määriteltä rajaa matalampi pistemäärä). Tämän kaltaisen autonomisen järjestelmän voi ajatella sopivan hyvin esimerkiksi pankkien henkilöasiakkaiden pienikokoisten kulutusluotto- ja luottokorttihakemusten arviointiin sen nopeuden ja pienen resurssitarpeen vuoksi. Esimerkkijärjestelmä kaksi (2) puolestaan kuvaa järjestelmää, joka samoin metodein laskee luottoa hakevan asiakkaan maksukykyä kuvaavan pistemäärän. Toisessa järjestelmässä luottopäätösten tekeminen ei

kuitenkaan ole kaikissa tilanteissa täysin autonomista. Pistemäärän päätyessä niin sanotulle ”harmaalle alueelle”, joka on määritelty alueena jonka sisällä järjestelmä ei kykene riittävään varmuuteen maksukykyennusteen osalta, luottopäätösasiantuntija analysoi tilanteen uudelleen ja tekee päätöksen oman näkemyksensä perusteella. Tämä, osittain asiantuntijan arvioon perustuva järjestelmä sopii hyvin esimerkiksi suurempien kotitalouksien tai yksityishenkilöiden hakemien luottojen, kuten asuntolainojen maksuhäiriöriskin arviointiin. Molemmissa järjestelmissä määritellyt pistemäärän rajat riippuvat pitkälti rahoituslaitoksen riskinsietokyvystä, strategiasta ja hinnoista. (Van Gestel & Baesens, 2009, s. 97–98.)

Luottihakemusten pisteyttämisen lisäksi rahoituslaitokset tai muut organisaatiot laativat pisteytyksiä yritysten ja henkilöiden luottohistoriasta asiakkuuksien aikana. Myös näitä arvioita käytetään tyypillisesti asiakkaan maksuhäiriöriskin arviointiin uusien luottopäätösten tekemisen yhteydessä. Siinä missä asiakkaan jatkuvan luotto- ja maksukäyttäytymisen arviointi toteutetaan Euroopassa rahoituslaitosten toimesta sisäisesti, esimerkiksi Yhdysvalloissa kyseinen toteutetaan luottovirastojen toimesta.

### 3.1.3 Perinteiset laskentamallit

Perinteiset, maksuhäiriöriskin arviointiin käytetyt matemaattiset mallit ovat tilastotieteen teoriaan nojaavia malleja. Nämä mallit pyrkivät määrittämään todennäköisyyden asiakkaan maksuhäiriölle ja näin ollen jakamaan luottoa hakevat osapuolet kahteen ryhmään; asiakkaat, jotka eivät todennäköisesti koe maksuhäiriötä ja asiakkaat, jotka kokevat. Olemassa olevien mallien erittäin suuren määrän vuoksi tässä tutkielmassa käsitellään suosituimpia laskentamalleja, joita analyyseissä hyödynnetään. Toinen syy tarkastelun rajaamiselle suosituimpiin malleihin on seuraava: rahoituslaitokset ja muut maksuhäiriöriskejä arvioivat toimijat tyypillisesti kehittävät malleja omiin käyttötarkoituksiinsa, käyttäen pohjana suosituimpia ja tehokkaimmiksi todettuja matemaattisia malleja. Näin ollen on kannattavaa vertailla perinteisiä malleja moderneihin ottamalla tarkasteluun suosituimmat ja tutkituimmat menetelmät, joiden soveltuvuutta ja suorituskykyä voidaan tarkastella universaalisti.

Suosituimmat tilastolliset mallit, jota tähän käyttötarkoitukseen rahoitusallalla sovelletaan, ovat lineaarinen diskriminaatioanalyysi ja sekä logistinen regressio (Moscatelli, Parlapiano, Narizzano & Viggiano, 2020). Näistä malleista ensimmäisen potentiaali konkurssien ja muiden maksuhäiriötilanteiden ennustamisessa tunnistettiin useita vuosikymmeniä sitten (Altman, 1983; Altman, 1968; Altman, Iwanicz-Drozdowska, Laitinen & Suvas, 2017 via Moscatelli, Parlapiano, Narizzano & Viggiano, 2020). Yksinkertaistetusti lineaarinen diskriminaatiomalli perustuu oletukseen siitä, että jokaiselle lainaa hakevalle osapuolelle on olemassa tietyt maksukykyä selittävät tekijät joiden lineaarikombinaation perusteella tutkittava populaatio voidaan jakaa mahdollisimman hyvin ja selkeästi kahteen luokkaan (ei todennäköistä maksuhäiriötä ja todennäköinen maksuhäiriö). Jako näihin kahteen luokkaan on sitä parempi ja diskriminoivampi, mitä suurempi näiden kahden luokan keskiarvojen välinen ero on. Lineaarisen diskriminaatioanalyysin vahvuudet ovat sen yksinkertaisuudessa ja toimivuudessa. Tämä metodi on kuitenkin saanut osakseen kritiikkiä johtuen sen riippuvuudesta populaatiota koskevien oletusten suhteen; malli ei toimi, mikäli populaatio ei noudata normaalijakaumaa. Maksuhäiriöriskin arviointia varten kerättävä data ei tyypillisesti täytä tätä kriteeriä tiettyjen muut, ainakaan ilman datan muokkausta. (Vojtek & Kočenda, 2006.) Tämä johtuu siitä, että osa luottohakemuksissa perinteisesti esiintyvistä asiakaskohtaisista muuttujaluokista noudattaa muita jakaumia. Lisäksi malli olettaa, että populaation sisäisten luokkien kovarianssimatriisit ovat identtiset. (Moscatelli, Parlapiano, Narizzano & Viggiano, 2020).

Toinen maksuhäiriöriskin määrittämisessä perinteisesti käytetty tilastollinen malli on logistinen regressio, jonka avulla voidaan tarkastella erilaisten luottoa hakevan asiakkaan parametrien vaikutusta asiakkaan maksuhäiriötodennäköisyyteen. Logistinen regressio voidaan luokitella tietyissä tilanteissa koneoppimismalliksi johtuen sen luokittelevasta toimintatavasta. Kyseessä on kuitenkin ennen kaikkea perinteinen metodi luotto- ja maksuhäiriöriskien hallinnassa, joten sitä ei tässä tutkielmassa luokitella moderneihin metodeihin. Malli perustuu selitettävän muuttujan todennäköisyyden ääriarvoihin ( $0 =$  ei maksuhäiriötä ja  $1 =$  maksuhäiriö) ja niiden todennäköisyyksiin (Moscatelli, Parlapiano, Narizzano & Viggiano, 2020, s. 3). Malli tutkii erilaisten, parametristen muuttujien vaikutusta tutkitavan tapahtuman

vedonlyöntitodennäköisyyksien (odds) suhteeseen ja itse tapahtuman todennäköisyyteen. Koska vedonlyöntitodennäköisyydet ja niiden suhdeluku (odds ratio) voivat vaihdella ainoastaan nollan ja äärettömän välillä, tapahtuman vedonlyöntitodennäköisyyksistä otetaan luonnollinen logaritmi. Tämän toimenpiteen avulla varmistetaan, että logistinen regressio toimii optimaalisella tavalla, ja että vedonlyöntitodennäköisyyksien suhteen muutoksia kuvaava regressiokerroin voi saada arvoja äärettömän pienten ja äärettömän suurten lukujen välillä. (Kaakinen & Ellonen, 2021.) Siinä missä logistinen regressiomalli ei perustu oletamaan molempien luokkien normaalijakaumaa noudattavasta rakenteesta eikä tee oletuksia luokkien kovarianssien yhtäsuuruudesta, mallin toimivuus on riippuvainen regressioanalyysille tyypillisistä oletamista, kuten siitä, että muuttujien välillä ei saa olla suurta multikollineaarisuutta, joka tarkoittaa korkeaa korrelaatiota riippumattomien muuttujien välillä. Lisäksi malli edellyttää, että yksittäiset havainnot eivät ole riippuvaisia keskenään (Kaakinen & Ellonen, 2021). Yleisesti ottaen lineaarisen regression heikkoudet aiemman multikollineaarisuusolettaman lisäksi liittyvät sen parametrisuuteen (Vojtek & Kočenda, 2006); malliin liittyy muuttujia ja niiden jakaumia koskevia oletamia, joiden myötä seuraavassa kappaleessa käsiteltävät ei-parametriset metodit voivat sopia maksuhäiriön todennäköisyyden määrittämiseen paremmin. Nämä oletamat ovat yleisesti ottaen kaikkien tilastollisten, perinteisten maksuhäiriöiden ja konkurssien ennustamiseen käytettyjen mallien heikkouksia (Wang & Ku, 2021), ja näin ollen niiden voidaan ajatella olevan syy uusien lähestymiskantojen etsintään luottoriskien arvioinnissa.

## 3.2 Modernit menetelmät

### 3.2.1 Yleistä

Viime vuosien aikana, erityisesti finanssikriisin jälkeen, rahoituslaitokset ovat ryhtyneet kiinnittämään huomiota maksuhäiriöriskin ja yleisesti ottaen asiakkaidensa maksukyvyyn tarkempaan arviointiin. Yritysten maksuhäiriö- ja luottoriskien arvioinnin sekä mittaamisen tapahtuessa vieläkin osittain manuaalisesti, henkilöasiakkaiden ja kotitalouksien arviointi toteutuu suurilta osin automatisoidusti. Tämä johtuu rahoituslaitosten kohtaamasta kotitalouksille ja yksityishenkilöille

suunnattujen tuotteiden suuresta kysynnästä, jonka seurauksena manuaaliset prosessit ja epätarkat sekä -tehokkaat menetelmät eivät sovellu maksuhäiriöriskin arviointiin. On myös huomioitava, että myönnettävien luottojen määrän ollessa äärimmäisen suuri, pienetkin parannukset maksuhäiriöitä ennustavissa malleissa ja prosesseissa voivat tuoda mittavia lisätuloja rahoituslaitoksille (Abellán & Castellano, 2016). Kuten aikaisemmassa perinteisiä metodeja käsitelleessä alaluvussa mainittiin, perinteisten maksuhäiriöriskin arviointiin käytettyjen mallien heikkoudet liittyvät niiden oletuksiin ja rajoituksiin koskien tutkittavaa aineistoa. Perinteiset mallit eivät toimi optimaalisesti valtavien, nykyaikana yleisten tietokantojen pohjalta toteutetuissa analyyseissa, joissa maksuhäiriötapahduman potentiaalisia selittäviä muuttujia voi olla suurikin määrä (Bao, Lianju & Yue, 2019). Näistä syistä rahoituslaitokset ovat pyrkineet löytämään uusia, nopeasti sopeutuvia malleja maksuhäiriöriskin analysointia varten. Näitä, usein koneoppimiseen tai tekoälyyn pohjautuvia data-analyysitekniikoita on syytä tutkia niiden tarjoamien mahdollisten hyötyjen vuoksi. Tutkielmassa käsitellyt modernit analyysitekniikat eroavat aiemmin käsitellyistä perinteisistä malleista erityisesti niiden ei-parametrisesta toimintatavasta johtuen. Mallit on jaettu kahteen eri luokkaan, joita käsitellään seuraavissa alaluvuissa. Käsittely tapahtuu havainnollistamalla mallien keskeisiä eroja ja vahvuusalueita yksinkertaistetusti. Tämä johtuu mallien monimutkaisuudesta ja tutkielman luonteesta, joka on tutkia mallien hyötyjä luottoriskien hallinnassa niiden matemaattisten ominaisuuksien sijasta.

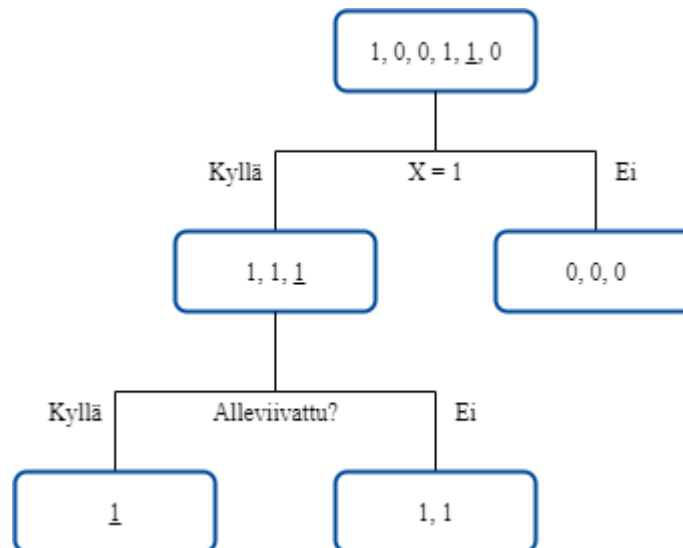
### 3.2.2 Ohjatut koneoppimisalgoritmit

Ohjatuilla koneoppimisalgoritmeilla tarkoitetaan data-analytiikassa käytettäviä ei-parametrisia malleja, joiden avulla pyritään kärjistetysti tutkimaan erilaisten tekijöiden vaikutusta tietyn tapahtuman lopputulokseen, sekä jakamaan erilaisia havaintoyksiköitä (luotto- ja maksuhäiriöriskin kontekstissa luottoa hakevia asiakkaita) kahteen eri luokkaan tämän lopputuloksen perusteella (Bao, Lianju & Yue, 2019, s. 302). Näiden mallien avulla pyritään asiakkaiden luokittelun lisäksi etsimään luottoa hakevien asiakkaiden ominaisuuksista ne yksittäiset parametrit, joilla on merkittävä vaikutus asiakkaan maksukykyyn. Tätä prosessia, jossa malli ”oppi” painottamaan erilaisia ominaisuuksia niiden merkittävyyden perusteella kutsutaan

mallin kouluttamiseksi. Kouluttaminen on perusedellytys mallin optimaaliselle toiminnalle – jos halutaan, että koneoppimismalli kykenee esimerkiksi jakamaan luotonhakijat maksuhäiriötahtuman todennäköisyyden perusteella mahdollisimman tarkasti niin sanottuihin hyviin ja huonoihin asiakkaisiin, mallin tulee ensin ymmärtää, mitkä asiat maksuhäiriön todennäköisyyteen vaikuttavat.

Luotto- ja maksuhäiriöriskin arviointiin soveltuvia ohjattuja algoritmeja on olemassa useita. Kuten perinteiset tilastolliset menetelmät, mallit pyrkivät jakamaan analysoitavan populaation mahdollisimman tarkasti kahteen luokkaan. Mallien toimintavoissa on kuitenkin eroja, jonka vuoksi tietyt mallit ovat suosituimpia maksuhäiriöriskien arvioinnissa. Suosituimpia malleja ovat tukivektorimalli (support vector machine, SVM) sekä keinotekoinen neuroverkkomalli (artificial neural networks, ANN) (Wang & Ku, 2021). Tukivektoreihin perustuva malli, jota Cortes ja Vapnik (1995) kuvasivat ensimmäisen kerran tutkimuksessaan, perustuu havaintoyksiköiden jakamiseen vektoreiden avulla, kun taas keinotekoinen neuroverkkomalli (Bishop, 1995) jakaa havaintoyksiköitä eri luokkiin jäljitellen ihmisaivojen toimintaa monimutkaisten yhteyksien löytämiseksi tekijöiden ja lopputuloksen välillä. (Bao, Lianju & Yue, 2019.)

Näiden koneoppimismallien lisäksi erilaiset päätöspuumallit (decision tree classifiers) ovat suosittuja binääristä luokittelua vaativissa tehtävissä (Lee, Chiu, Chou & Lu, 2006). Päätöspuumalleissa havaintoyksiköt jaetaan kahteen luokkaan portaissa hyödyntäen puuta muistuttavaa graafia, joka koostuu solmukohdista ja oksista. Päätöspuumalleissa jokainen solmukohta edustaa jotain otannan ominaisuutta ja oksa puolestaan kyseisen ominaisuuden arvoa (Abellán & Castellano, 2016; Bao, Lianju & Yue, 2019.) Seuraavassa kuviossa havainnollistetaan yksinkertaistetusti päätöspuumallin luokitteluprosessia.



**Kuvio 4. Yksinkertainen päätöspuu (mukaillen Yiu, 2019).**

Kuten kuvioista on tulkittavissa, päätöspuumallit voidaan esittää hyvin ymmärrettävässä muodossa visuaalisesti. Ennustustarkkuuden ja ei-parametrisen, sopeutuvan toimintaperiaatteen lisäksi tämän ominaisuuden voidaan ajatella olevan osasyys päätöspuuluokittelijoiden suosioon data-analyysissä. Vaikka päätöspuumallien tarkkuus ja luokittelukyky onkin riittävä niiden hyödyntämiseksi binäärisessä luokittelussa, erilaisia päätöspuukokonaisuuksia rakentavia malleja on kehitetty tarkkuuden parantamiseksi. Tällaisia malleja ovat esimerkiksi Random Forest -malli (RF) (Breiman, 2001) ja Gradient boosting decision trees -malli (GBDT) (Friedman, 2001). RF-malli parantaa yksittäisen päätöspuuanalyysin tehokkuutta suorittamalla useita päätöspuuanalyyssejä samanaikaisesti, ja lopulta tekee luokittelun valitsemalla tuloksen suoritettujen päätöspuiden konsensuksen mukaan. GBDT-malli puolestaan parantaa päätöspuumallin tehokkuutta suorittamalla analyyssejä peräkkäin, vaihtaen populaation ominaisuuksien painotuksia aina edellisen analyysin mukaisesti tärkeysjärjestyksessä. GBDT-mallin nimi tuleekin yllä avatusta toimintaperiaatteesta, jonka mukaan malli muokkaa perustason päätöspuuanalyysin tarkaksi parantamalla sitä edellisen perusteella.

### 3.2.3 Ohjaamattomat koneoppimisalgoritmit

Ohjaamattomat koneoppimismallit, joilla tarkoitetaan useimmissa tapauksessa eräänlaisia havaintoyksiköiden ryhmittelyyn eli klusterointiin sopivia malleja, eroavat



ohjatuista koneoppimis- ja tekoälymalleista niiden käyttötarkoituksen ja toimintaperiaatteen vuoksi. Ohjattujen mallien keskittyessä luomaan ennusteita havaintoyksiköstä, ohjaamattomia malleja käytetään lähinnä datan louhimiseen ja erilaisten ryppäiden eli klusterien tunnistamiseen populaation sisällä. (Bao, Lianju & Yue, 2019.) Tällaisia malleja ovat esimerkiksi k-means -klusterointialgoritmi ja Kohosen (1998) kehittämä malli nimeltä self-organizing maps. Molempien algoritmien ollessa hyvin monimutkaisia, niiden varsinaisia toimintaperiaatteita tai matemaattisia ominaisuuksia ei käsitellä tässä tutkielmassa laajemmassa mittakaavassa. Sen sijaan on tärkeää ymmärtää, että ohjaamattomia koneoppimis- ja tekoälyalgoritmeja hyödynnetään luotto- ja maksuhäiriöriskien analysoinnin kontekstissa lähinnä ohjattujen mallien yhteydessä. Klusterointia voidaan hyödyntää esimerkiksi populaation jakamisessa ryhmiin ennen varsinaista maksuhäiriön todennäköisyyteen perustuvaa luokittelua. (Bao, Lianju & Yue, 2019.) Näin voidaan parantaa itse luokitteluprosessin tarkkuutta.

## 4 PERINTEISTEN JA MODERNIEN MENETELMIEN VERTAILU

Luottoriskien ja tämän tutkielman osalta maksuhäiriöriskin hallinnassa hyödynnetään useita erilaisia metodeja ja malleja, joita on käsitelty edeltävässä pääluvussa. Kaikkia tutkielmassa esiteltyjä tilastollisia malleja ja tekoälyä soveltaviksi luokiteltavia metodeja hyödynnetään todistetusti maksuhäiriöriskien arvioinnissa ja sen myötä päätöksenteossa, jolla on suora vaikutus rahoituslaitosten liiketoiminnan kannattavuuteen. Tästä syystä on tärkeää tarkastella erilaisten analyysimetodien eriäväisyyksiä liiketoiminnalliset näkökulmat huomioon ottaen. Lisäksi on hyvä tiedostaa, ettei yksikään aiemmassa pääluvussa mainituista menetelmistä ole kaikissa maksuhäiriöriskien analysointiin liittyvissä tehtävissä paras. Toisin sanoen, käyttötarkoitus ja vallitsevat olosuhteet, esimerkiksi tutkimusaineistoa koskien, vaikuttavat optimaalisen metodin valintaan.

Tässä pääluvussa vertaillaan erilaisten mallien vahvuuksia ja heikkouksia seuraavien alalukuihin jaettujen kategorioiden kautta. Vertailu on toteutettu olemassa olevan tutkimuskirjallisuuden pohjalta. Ensimmäisessä alaluvussa (tarkkuus) vertailu toteutetaan olemassa olevan tutkimuskirjallisuuden sisältämien datalähtöisten analyysitulosten perusteella. Liiketoiminnallisia vaikutuksia käsittelevässä alaluvussa vertaillaan perinteisiä ja moderneja metodeja liiketoiminnallisten vaikutusten näkökulmasta.

### 4.1 Tarkkuus

#### 4.1.1 Mittaussyöret

Maksuhäiriöriskin arvioinnin ja minimoinnin kannalta kaikista tärkein analyysimetodin ominaisuus on sen tarkkuus. Tarkkuutta voidaan mitata monen erilaisen tunnusluvun avulla. Tämä tutkielma tarkastelee metodien luokittelukykyä tutkimuskirjallisuuden käsittelemien tunnuslukujen avulla. Yksi näistä tunnusluvuista on AUC-arvo (area under the curve), joka liittyy luokittelijoiden suorituskykyä havainnollistavaan usein käytettyyn ROC-käyrään (receiver operating characteristic). AUC-arvo mittaa mallin todennäköisyyttä antaa satunnaisesti valitulle positiiviselle

(1, maksuhäiriö) havaintoyksikölle korkeampi maksuhäiriön todennäköisyys kuin satunnaisesti valitulle negatiiviselle (0, ei maksuhäiriötä) havaintoyksikölle. Luokittelevien mallien AUC-arvo vaihtelee välillä 0,5–1 siten, että täydellisesti luokittelevan mallin saama luku on yksi ja täysin satunnaisesti luokitteleva malli saa luvun 0,5. (Fawcett, 2006.) Toinen mittaussuure, jota käytetään usein mallien vertailussa on tarkkuusluku (accuracy, ACC), joka mittaa oikein luokiteltujen havaintoyksiköiden (oikein positiiviseksi luokitellut tulokset + oikein negatiiviseksi luokitellut tulokset) määrän suhdetta kaikkien havaintoyksiköiden määrään. ACC ei kuitenkaan anna luotettavaa kuvaa mallin luokittelukykyvystä tilanteissa, jossa analysoitava aineisto ei ole tasapainoinen. Maksuhäiriöitä ennustettaessa tämä osoittautuu usein ongelmalliseksi maksuongelmaisten asiakkaiden ollessa harvinaisempia kuin asiakkaat, jotka maksavat luottonsa ajoissa ilman häiriöitä. Parempi mittaussuure tähän tarkoitukseen on Matthews sin korrelaatiokerroin, joka antaa luotettavamman kuvan luokittelumallin tarkkuudesta. (Bao, Lianju & Yue, 2019; Chicco & Jurman, 2020.) Kerroin mittaa nimensä mukaisesti havaintoyksiköiden ennustettujen ja todellisten luokkien korrelaatiota. Kerroin saa arvoja välillä [-1, 1] siten, että kun MCC = 1, mallin ennustamat luokat vastaavat täysin todellisia luokkia. (Bao, Lianju & Yue, 2019.)

Sekä ACC, että MCC johdetaan luokittelutarkkuuden mittaamiseen käytetystä konfuusiomatriisista (confusion matrix). Esimerkkitaulukossa 1 havainnollistetaan konfuusiomatriisi, jonka jälkeen havainnollistetaan tarkkuusluvun (kaava 1) ja Matthews sin korrelaatiokertoimen (kaava 2) laskentakaavat.

**Taulukko 1. Luokittelumallien konfuusiomatriisi maksuhäiriöriskin ennustamisessa.**

	<b>Luokka 1 (maksuhäiriö)</b>	<b>Luokka 0 (ei maksuhäiriötä)</b>
<b>Luokka 1 (maksuhäiriö)</b>	Todellinen positiivinen (TP)	Väärä negatiivinen (FN)
<b>Luokka 0 (ei maksuhäiriötä)</b>	Väärä positiivinen (FP)	Todellinen negatiivinen (TN)

Sininen väri edustaa taulukossa havaintoyksiköille ennustettuja luokkia ja harmaa väri havaintoyksiköiden todellisia luokkia.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (2)$$

Molemmat laskentakaavat perustuvat siis konfuusiomatriisissa eriteltyihin havaintoluokkiin ja luokittelutarkkuuden mittaamiseen luokkien suhteiden perusteella. Myös kaavoista on huomattavissa aiemmassa kappaleessa todettu ero mittaussuureiden välillä. Matthews sin korrelaatiokerroin ja sen antama tulos kuvaa myös analyysin konfuusiomatriisia laajemmin kuin ACC (Bao, Lianju & Yue, 2019). Vaikka yllä esiteltyt mittaussuureet ovat suosituimpia tapoja tulkita luokittelumallien tarkkuutta, mallien vertailuun käytettävät suureet vaihtelevat tutkimuskirjallisuuden välillä. Tästä syystä tutkielmassa on jouduttu käyttämään malleja vertailtaessa myös muita mittaussuureita, kuten Brierin lukua, joka mittaa keskimääräistä eroa ennustetun ja todellisen tapahtumatodennäköisyyden välillä.

#### 4.1.2 Vertailu


Kruppa, Schwarz, Arminger ja Ziegler (2013) vertailevat tutkimuksessaan erilaisia koneoppimismalleja ja niiden luokittelutehokkuutta referenssimallina käytettävään logistiseen regressioon. Kodinkonehankintojen rahoitukseen liittyvän data-aineiston avulla tehtävä vertailu tapahtuu aineiston pohjalta luotujen mallikohtaisten maksuhäiriöennusteiden perusteella. Tutkimuksessa mallien ennustustarkkuutta mitataan kahdella tavalla: AUC-arvolla ja Brierin luvulla. Taulukko 1 havainnollistaa tutkimuksen tuloksia RF-mallin, kahden erilaisen logistisen regressioanalyysin ja kahden muun koneoppimismallin osalta. Vertailu tapahtuu yllä mainittujen mittaussuureiden sekä niiden 95 % luottamusvälin avulla.

**Taulukko 2. Random Forest -mallin, kNN-mallin, bNN- mallin ja logistisen regressiomallin vertailu (mukaillen Kruppa, Schwarz, Arminger & Ziegler, 2013).**

	AUC	BS
<b>RF</b>	0,959 (0,956; 0,963)	0,071 (0,068; 0,074)
<b>logReg tuned</b>	0,779 (0,768; 0,792)	0,103 (0,099; 0,107)
<b>logReg</b>	0,748 (0,737; 0,760)	0,110 (0,106; 0,114)
<b>kNN</b>	0,685 (0,672; 0,698)	0,116 (0,112; 0,120)
<b>bNN</b>	0,681 (0,667; 0,693)	0,117 (0,113; 0,121)

Kuten taulukko osoittaa, tutkimuksen mukaan RF-malli suoriutuu paremmin tutkimuksessa käytetyn aineiston luokittelussa hyviin ja huonoihin luotonhakijoihin, kuin perusmuotoinen tai asiantuntijan määrittämä logistinen regressiomalli. Tämä toteutuu sekä AUC-arvon, että Brierin luvun osalta, eron ollessa RF-mallin ja asiantuntijan määrittämän logistisen regression välillä AUC-arvolla mitattuna 0,180 ja Brierin luvulla mitattuna 0,032. Pelkästään tämän tutkimuksen ja sen tulosten perusteella ei kuitenkaan voida tehdä johtopäätöksiä koneoppimis- ja tekoälymallien yliveraisuudesta verrattuna perinteisiin metodeihin. Mallien suorituskyvyn ollessa riippuvainen tutkittavan aineiston muodosta ja mallin käyttötarkoituksesta, tulee johtopäätösten muodostamiseksi ottaa huomioon myös muita tutkimuksia.

Bao ym. (2019) vertailevat erilaisten ohjattujen ja ohjaamattomien koneoppimis- sekä tekoälymallien suorituskyyä maksuhäiriöriskin ennustamistehokkuuden perusteella hyödyntäen kolmea erilaista luottotietokantaa. Tutkimuksessa arvioidaan yleisimpiä ja tutkituimpia malleja, joiden suorituskyyä mitataan muun muassa aiemmassa alaluvussa käsiteltyjen mittaussuureiden avulla. Erityistä painoarvoa tutkimuksessa annetaan Matthews sin korrelaatiokertoimelle. Lisäksi tutkimuksessa arvioidaan ohjaamattomien koneoppimis- ja tekoälymallien kykyä parantaa ohjattujen mallien ennusteita. Kuvio 5 havainnollistaa tutkimuksen tuloksia eri mallien suorituskyyvystä Matthews sin korrelaatiokertoimella mitattuna. Sininen palkki mittaa mallin suorituskyyä ilman aineiston klusterointia, ja harmaa palkki mallin suorituskyyä, kun se on rakennettu klusteroidun aineiston avulla.



**Kuvio 5. Mallien vertailu MCC:n avulla (mukaillen Bao, Lianju, Kong, 2019).**

Kuviossa 5 esitellyt tutkimustulokset tukevat edistyneiden koneoppimis- ja tekoälymallien parempaa tarkkuutta verrattuna perinteisiin metodeihin. Kaikki tutkimukseen sisällytetyt edistyneet metodit, pois lukien päätöspuuanalyysi, suoriutuvat MCC:llä mitattuna luokittelutehtävässä paremmin kuin logistinen regressioanalyysi. Tämä tulos pätee myös ACC:n osalta. AUC-arvolla mitattuna logistinen regressio pärjää kuitenkin edistyneemmille malleille hyvin, erityisesti kun data-aineisto on klusteroitu. Huomion arvoista on lisäksi se, että kun mallien räätälöintiin käytettävä data-aineisto klusteroidaan tekijöiden perusteella alaluokkiin, mallien suorituskky tyypillisesti paranee. Tätä väitettä tukee yllä olevan kuvion lisäksi muut tutkimuksen analyysit, jotka perustuvat eri data-aineistoihin. (Bao, Lianju & Yue, 2019.) Tämä viittaa siihen, että parhaaseen tulokseen maksuhäiriöriskin arvioinnissa päästään yhdistämällä sekä ohjattuja, että ohjaamattomia koneoppimis- ja tekoälymalleja. Yleisesti voidaan ajatella, että useamman mallin soveltaminen erikseen tai rinnakkain johtaa tyypillisesti parempaan tarkkuuteen kuin yhden mallin hyödyntäminen kertaluontoisesti. Tätä tukee yllä mainittujen tutkimusten lisäksi myös tutkimus, jossa Florez-Lopez ja Ramon Jeronimo (2015) tutkivat erilaisten mallikokonaisuuksien rakentamisen vaikutuksia maksuhäiriöriskin määrittystarkkuuteen. Kyseinen tutkimus on hyvin vertailukelpoinen, sillä sen

pääasialliset mittaussuureet olivat ACC ja AUC-arvo, joita on hyödynnetty myös muussa tutkielman tutkimuskirjallisuudessa mallien tarkkuuden mittaamiseen.

Aiemman lisäksi voidaan todeta, että ilman data-aineiston klusterointia, tutkimuksen kaksi vanhinta analyysimetodia (päättöspuumalli ja logistinen regressio) suoriutuvat tutkimuksen luokittelutehtävistä keskimäärin huonommin kuin edistyneemmät mallit. Päättöspuumallin puolustuksesi on kuitenkin todettava, että se toimii perustana muille malleille, jotka ovat keskimäärin suorituskkyisempiä kuin tutkielman käsittelemät perinteiset tilastolliset analyysimetodit. Näitä ovat esimerkiksi GBDT-malli sekä RF-malli, jotka ovat todistetusti tehokkaita välineitä maksuhäiriöriskin ennustamisessa ja hallinnassa. Tämä käy ilmi aiemmin käsitellyn tutkimuskirjallisuuden lisäksi esimerkiksi Yun (2020) toteuttamassa tutkimuksessa, jossa analysoidaan logistisen regression, päätöspuiden, AdaBoosting -algoritmin sekä RF-mallin suorituskkyä maksuhäiriöriskin ennustamisessa. Tutkimustulokset ovat linjassa muiden tutkimusten kanssa: RF-malli suoriutui tehtävästä parhaiten, logistinen regressio heikoiten.

Perinteisen, subjektiivisen arvioinnin vertaaminen moderneihin malleihin tutkielmassa käytettävien mittaussuureiden avulla on hankalaa. Tämän lisäksi kyseinen vertailu ei ole kannattavaa, sillä puhtaasti asiantuntijan osaamiseen perustuva maksuhäiriöriskin määrittäminen ei sovellu nykyaikaiseen, nopeaan ja erittäin kilpailtuun luottomarkkinaympäristöön sen hitauden vuoksi. Tietyissä tilanteissa, kuten kolmannessa pääluvussa mainituissa edistyneempien mallien tuottamissa rajatapauksissa subjektiivinen arviointi voi kuitenkin olla tarpeen. Maksuhäiriöriskin arvioinnin nopeusvaatimukset riippuvat hyvin paljon potentiaalisen asiakassuhteen ja kyseessä olevan luottotuotteen laadusta. Henkilöasiakkaiden luottomarkkinoilla maksuhäiriöriski tulee kyetä arvioimaan erittäin nopeasti, kun taas erityisesti suurten yritysluottojen suhteen arviointiin voi olla perusteltua käyttää suurikin määrä asiantuntijaosaamista. Toisaalta on myös huomioitava, että yritysten arviointiin on käytettävissä huomattavasti suurempi määrä tietoa löyhemmistä tietosuoja-asetuksista johtuen. Tämän vuoksi automatisoiduilla järjestelmillä voidaan mahdollisesti päästä tarkempiin tuloksiin yritysten arvioinnissa. Markkinatilanteiden ja rahoituslaitoskohtaisten liiketoiminnallisten tavoitteiden vaihdellessa suuresti, jokaisen toimijan on löydettävä itselleen sopivat metodit luotto- ja maksuhäiriöriskien

arviointiin. Olemassa olevan tutkimuskirjallisuuden perusteella voidaan kuitenkin todeta, että tässä tutkiemassa käsiteltyt modernit koneoppimismallit suoritutuvat keskimäärin paremmin luotonhakijoiden luokittelusta hyviin ja huonoihin asiakkaisiin maksuhäiriöriskin perusteella verrattuna perinteisiin menetelmiin.

## 4.2 Liiketoiminnalliset vaikutukset

Luotto- ja maksuhäiriöriskien arviointimetodit ja niiden optimaalinen valinta tähtää liiketoiminnan tuottojen maksimointiin. Eri metodien liiketoiminnallisia vaikutuksia on syytä tarkastella syvällisesti optimaalisen yhdistelmän löytämiseksi, joka samaan aikaan minimoi liiketoiminnan luottotappiot ja pitää arvioinnin kulut maltillisena. Kilpailtu luottomarkkina, jossa ostaja valitsee haluamansa luoton eri rahoituslaitosten tarjoamista vaihtoehdoista (Van Gestel & Baesens, 2009, s. 96), edellyttää rahoituslaitoksilta kykyä hyvät ja huonot asiakkaat mahdollisimman hyvin tuottojen maksimoimiseksi ja tappioiden minimoimiseksi. Liiketoiminnallisesti kannattavan, maksuhäiriöriskin arviointiin käytettävän metodiyhdistelmän valinnan yhteydessä tulee näistä syistä tarkastella menetelmän tehokkuuden ja käytöstä aiheutuvien kustannusten suhdetta. Tutkielman käsittelemien data-analyysimallien osalta kustannukset muodostuvat mallien räätälöintiin vaadittavan työvoiman kustannuksista, laskentatehon tarpeesta sekä muista implementointikustannuksista, kuten laiteinvestoinneista. Tehokkuuden voidaan puolestaan ajatella koostuvan menetelmän luokittelutarkkuudesta ja tulosten sovellettavuudesta.

Perinteiset metodit, kuten subjektiivinen arviointi, luottopisteytys tuloskortin avulla ja tilastolliset mallit (lineaarinen diskriminaatioanalyysi ja logistinen regressio) ovat edelleen tärkeässä roolissa rahoituslaitosten maksuhäiriöriskin arviointiprosesseissa. Tämä johtuu osin siitä, että kyseisten menetelmien rooli maksuhäiriöriskin arviointiprosessissa on vakiintunut ja niiden toimintaperiaatteet ovat helposti ymmärrettävissä. Jotta maksuhäiriöriskin arviointiin käytettävä malli on hyödyllinen, sen tulee olla sekä tarkka, että ymmärrettävä. Tästä syystä rahoituslaitokset eivät ole aiemmin halunneet ottaa modernimpia menetelmiä käyttöön, mallien toimintaperiaatteiden ollessa erittäin vaikeita ymmärtää. (Florez-Lopez & Ramon-Jeronimo, 2015.)



Kuten tutkielman edellisessä alaluvussa on todettiin, modernit menetelmät ovat keskimäärin tarkempia erottamaan hedelmälliset asiakkuudet huonoista. Tarkkuuden osalta voidaan siis olettaa, että modernit mallit tukevat rahoituslaitosten liiketoiminnallisia tavoitteita keskimäärin paremmin kuin perinteiset mallit. Yksinkertaisemmat ja epätarkemmat mallit ovat puolestaan kevyempiä, helpompia ymmärtää ja halvempia käyttää implementointikustannusten, räätälöintiin käytettävän työmäärän, sekä laskentatehon osalta. Näistä havainnoista päästään kysymykseen, joka kohtaa liiketoimintaa optimaalisten metodien valinnan yhteydessä: ovatko tarkkuuden paranemisen seurauksena saatavat lisätuotot suuremmat, kuin tarkempien menetelmien käytöstä aiheutuvat kustannukset. Yksiselitteistä vastausta tähän kysymykseen ei ole. Riskienhallinnan perspektiivistä tarkempien menetelmien implementoinnille on kuitenkin useita syitä, kuten vastuun kantaminen maailmantalouden vakaudesta, sekä modernien mallien muut ominaisuudet jotka auttavat rahoituslaitoksia valvomaan asiakassuhteita tehokkaammin sekä tunnistamaan maksuhäiriöön johtavat tekijät. Globaalin finanssikriisin seurauksena kasvanut rahoituslaitosten toimintaa koskeva sääntely edellyttää lisäksi entistä parempia riskienhallintaprosesseja osana rahoituslaitosten toimintaa (Bank for International Settlements, 2011).

## 5 YHTEENVETO

Tämän tutkielman tavoitteena on ollut tarkastella erilaisia luotto- ja erityisesti maksuhäiriöriskin arviointiin käytettäviä analyysimenetelmiä ja malleja niiden tilastollisen tarkkuuden ja liiketoiminnallisten hyötyjen kautta. Samalla on pyritty vastaamaan tutkimuskysymykseen: mitä hyötyjä edistyneiden data-analyysimenetelmien ja mallien käytöllä saavutetaan luottoriskejä hallittaessa? Tutkielmassa on perehdytty ensin luottoriskejä muodostaviin komponentteihin ja käsitteisiin, minkä jälkeen on perehdytty erityisesti maksuhäiriöriskin arviointiin ja kyseisessä prosessissa hyödynnettäviin menetelmiin. Näitä menetelmiä on vertailtu tutkielmassa ensin teknisten erityispiirteiden ja sen jälkeen tarkkuuden sekä liiketoiminnallisten vaikutusten kautta. Aiemmasta tutkimuskirjallisuudesta poiketen tämän tutkielman tarkoitus ei ole ollut tutkia edistyneiden mallien matemaattisia ominaisuuksia ja mallien taustateorioita syvällisesti tai kuvata niitä yksityiskohtaisesti. Sen sijaan tutkielman tavoitteena on ollut tutkimuskysymykseen vastaamisen lisäksi luoda ymmärrys luottoriskin tekijöistä ja maksuhäiriöriskin arviointiprosessista, jonka avulla rahoituslaitokset muodostavat luottopäätöksiä.

Vertailun myötä tutkielman tulokset ja näin ollen vastaukset tutkimuskysymykseen voidaan tiivistää seuraaviin havaintoihin. Edistyneiden data-analyysimenetelmien, kuten koneoppimisalgoritmien hyödyntämisellä luotto- ja maksuhäiriöriskien hallinnassa voidaan saavuttaa merkittäviä etuja verrattuna perinteisiin analyysimenetelmiin. Näitä etuja ovat parempi luokittelukyky hyviin ja huonoihin asiakkaisiin sekä parempi kyky tunnistaa tekijät, jotka vaikuttavat eniten asiakkaiden maksukykyyn. Paremman luokittelukykyyn ansiosta luotonantajat kykenevät minimoimaan luottotappioita tehokkaammin. Vaikka tutkielman käsittelemien edistyneiden analyysimenetelmien implementointi voi aiheuttaa kustannuksia lyhyellä aikavälillä, pitkällä aikavälillä investoinnit kyseisiin menetelmiin ovat kannattavia niin liiketoiminnallisesta kuin yhteiskunnallisesta näkökulmasta. Rahoituslaitosten liiketoiminnallinen tuloksentekeytyminen paranee, kun menetelmät tarkentuvat ja hyvät asiakkuudet tunnistetaan tehokkaasti. Tällöin luottoja ei myönnetä myöskään yhtä paljon asiakkaille, jotka eivät lopulta suoriudu maksuvelvoitteistaan. On erityisen tärkeää ymmärtää, että pienikin parannus maksuhäiriöriskiä ennustavan mallin

luokittelutarkkuudessa voi tarkoittaa erittäin suuria lisätuloja rahoituslaitokselle. Edistyneiden mallien välillä on kuitenkin yhteisen potentiaalin lisäksi merkittäviä soveltuvuuteen liittyviä eroja, joiden vuoksi rahoituslaitosten tulee etsiä sopiva malli käyttötarkoituksen mukaan.

Aiempi tutkimuskirjallisuus tukee tämän tutkielman tuloksia hyvin. Lisäksi tulokset ovat linjassa olemassa olevien rahoituslaitosten nykyisen toiminnan kanssa. Menetelmien kehitys ja edistynyt data-analytiikka osana luottoriskien hallintaa on nähtävissä erityisesti henkilöasiakkaiden ja kotitalouksien luottomarkkinoissa, joissa luottopäätöksen voi saada parhaimmillaan tunneissa. Nopeat luottopäätökset voivat viitata siihen, että rahoituslaitokset luottavat automatisoitujen analyysimenetelmien tarkkuuteen niin paljon, että tiettyjen reunaehtojen ollessa voimassa asiantuntijan osaamista ei tarvita luottopäätökseen lainkaan.

Aiemman tutkimuskirjallisuuden keskittyessä lähinnä mallien matemaattiseen toimintaan ja niiden testaamiseen erilaisten aineistojen avulla tämän tutkielman luoma arvo liittyy erityisesti olemassa olevien tutkimustulosten kokoamiseen ja vertailuun. Lisäksi tutkielma antaa lukijalle selkeän kuvan luottoriskin tekijöistä ja maksuhäiriöriskin arviointiprosessista, joka on rahoituslaitosten tärkein yksittäinen riskienhallintaprosessi. Mahdollisia jatkotutkimuskysymyksiä on useita, koska tutkielma käsittelee erilaisia malleja kirjallisuuskatsauksen kautta ilman empiiristä analyysiä. Aiheen kannalta luonnollinen jatkumo olisi tutkia mallien suorituskykyä empiirisesti eri tavoin painotettujen data-aineistojen avulla, jolloin kyettäisiin tutkimaan esimerkiksi muuttujaluokkien erilaisten jakaumien vaikutuksia tarkkuuteen. Olisi myös mielenkiintoista tutkia erilaisia maksuhäiriöriskin arviointiin kehitettyjä keskitettyjä ratkaisuja, joita rahoituslaitokset voisivat mahdollisesti hyödyntää asiakkaan roolissa. Toisaalta olisi myös aiheellista tutkia erilaisten mallien hyödyntämistä kansallisten rahoituslaitosten maksuhäiriöriskin arviointiprosesseissa anonyymien kyselytutkimuksen avulla, jolloin käytetyimpiä menetelmiä olisi mahdollista tutkia eri skenaarioissa. Kuten Vojtek ja Kočenda (2006) osoittavat, pankit ovat käyttäneet edistyneitä, ei-parametrisia malleja ennen finanssikriisiä lähinnä perinteisten tilastollisten mallien tukena, eikä niiden potentiaalia ole aiemmin hyödynnetty täysin.

## LÄHTEET

- Abbadi, S. M. & Abu Karsh, S. M. (2013). Methods of evaluating credit risk used by commercial banks in Palestine. *International Research Journal of Finance and Economics*, 111(1), 146–159.
- Abellán, J. & Castellano, J. G. (2016). A comparative study on base classifiers in ensemble methods for credit scoring. *Expert Systems With Applications*, 73(1), 1–10. doi:10.1016/j.eswa.2016.12.020
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609.
- Altman, E. I. (1983). *Corporate Financial Distress: A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. New Jersey: John Wiley & Sons.
- Altman, E. I., Iwanicz-Drozowska, M., Laitinen, E. K. & Suvas, A. (2017). Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-Score model. *Journal of International Financial Management and Accounting*, 28(2), 131–171. doi:10.1111/jifm.12053
- Bank for International Settlements. (2011). Basel III: A Global framework for more resilient banks and banking systems. *Basel Committee on Banking Supervision*.
- Bao, W., Lianju, N. & Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems With Applications*, 128(1), 301–315. doi:10.1016/j.eswa.2019.02.033
- Benz, G. V. (1979). *International trade credit management*. Iso-Britannia: Gower Press Limited.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. New York: Oxford University Press.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. doi:10.1023/A:1010933404324
- Chicco, D. & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(6). doi:10.1186/s12864-019-6413-7
- Corporate Finance Institute. (2021). *5 Cs of Credit*. Noudettu osoitteesta <https://corporatefinanceinstitute.com/resources/knowledge/credit/5-cs-of-credit/>

- Cortes, C. & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. doi:10.1007/BF00994018
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(1), 861–874. doi:10.1016/j.patrec.2005.10.010
- Fight, A. (2004). *Credit Risk Management*. Amsterdam: Elsevier. doi:10.1016/B978-0-7506-5903-1.X5000-8
- Florez-Lopez, R. & Ramon-Jeronimo, J. M. (2015). Enhancing accuracy and interpretability of ensemble strategies in credit risk assessment. A correlated-adjusted decision forest proposal. *Expert Systems with Applications*, 42(1), 5737–5753. doi:10.1016/j.eswa.2015.02.042
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232. Noudettu osoitteesta <http://www.jstor.org/stable/2699986>
- Kaakinen, M. & Ellonen, N. (2021). *Regressioanalyysin oletukset*. Noudettu osoitteesta Kvantitatiivisen tutkimuksen verkkokäsikirja: <https://www.fsd.tuni.fi/fi/palvelut/menetelmaopetus/kvanti/regressio/oletukset/>
- Kohonen, T. (1998). The self-organizing map. *Neurocomputing*, 21(1–3), 1–6. doi:10.1016/S0925-2312(98)00030-7
- Kruppa, J., Schwarz, A., Armingier, G. & Ziegler, A. (2013). Consumer credit risk: Individual probability estimates. *Expert Systems with Applications*, 40(13), 5125–5131. doi:10.1016/j.eswa.2013.03.019
- Lee, T.-S., Chiu, C.-C., Chou, Y.-C. & Lu, C.-J. (2006). Mining the customer credit using classification and regression tree and multivariate adaptive regression splines. *Computational Statistics & Data Analysis*, 50(4), 1113–1130. doi:10.1016/j.csda.2004.11.006
- Moscatelli, M., Parlapiano, F., Narizzano, S. & Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 161(1). doi:10.1016/j.eswa.2020.113567
- Resti, A. & Sironi, A. (2014). *Risk management and shareholders' value in banking: from risk measurement models to capital allocation policies*. New Jersey: John Wiley & Sons. doi:10.1002/9781118371886

- Treacy, W. F. & Carey, M. (2000). Credit risk rating systems at large US banks. *Journal of Banking & Finance*, 24(1–2), 167–201. doi:10.1016/S0378-4266(99)00056-4
- Van Gestel, T. & Baesens, B. (2009). *Credit Risk Management: Basic Concepts: Financial Risk Components, Rating Analysis, Models, Economic and Regulatory Capital*. Englant: Oxford University Press.
- Vojtek, M. & Kočenda, E. (2006). Credit Scoring Methods. *Czech Journal of Economics and Finance (Finance a uver)*, 56(3-4), 152–167. Noudettu osoitteesta [http://journal.fsv.cuni.cz/storage/1050\\_s\\_152\\_167.pdf](http://journal.fsv.cuni.cz/storage/1050_s_152_167.pdf)
- Wang, M. & Ku, H. (2021). Utilizing historical data for corporate credit rating assessment. *Expert Systems with Applications*, 165(1). doi:10.1016/j.eswa.2020.113925
- Yiu, T. (2019). *Understanding Random Forest*. Noudettu osoitteesta Towards Data Science: <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>
- Yu, Y. (2020). The Application of Machine Learning Algorithms in Credit Card Default Prediction. *International Conference on Computing and Data Science (CDS)*, 212–218. doi:10.1109/CDS49703.2020.00050